

## ANALISA AKAR MASALAH RADIAL RUN OUT BAN MENGGUNAKAN DECISION TREE

Bambang Biantoro<sup>1</sup>, Hernadewita<sup>2</sup>

<sup>1</sup>Jurusan Teknik Industri, Universitas Mercubuana Jakarta

Email: b\_biantoro@yahoo.com

<sup>2</sup>Departemen Teknik Industri, Universitas Mercubuana Jakarta

Email: hernadewita@mercubuana.ac.id

Masuk: 01-10-2020, revisi: 06-10-2021, diterima untuk diterbitkan: 27-10-2021

### ABSTRAK

Pemecahan masalah pada proses produksi *multistage* merupakan tantangan untuk industri. Pemanfaatan teknik modern seperti *machine learning* dalam pemecahan masalah kualitas terus dikembangkan. Salah satu *machine learning* adalah *decision tree*. Industri ban memasuki era industri revolusi 4.0 dengan adanya pemakaian teknologi informasi seperti *barcode* atau *radio frequency identification*. Pemanfaatan data dengan menggunakan *machine learning* dalam pencarian akar masalah bisa mendukung industri ban dalam kompetisi industri. Penelitian ini bertujuan untuk mengeksplorasi data proses pada industri ban untuk memecahkan permasalahan kualitas ban yaitu *radial run-out* ban. Teknik pencarian akar masalah dilakukan menggunakan *Classification and Regression Tree* (CART). Variabel *input* melibatkan 60 faktor dalam proses produksi. Dari penelitian didapatkan faktor yang mempengaruhi nilai *radial run out* adalah lot komponen *Tread*, *Bead* dan *Sidewall*. Untuk faktor penyebab tingginya *radial run-out* ban adalah variasi lot komponen *Tread* dan *Bead*. Model *decision tree* yang terbentuk memiliki tingkat presisi 74,7% dalam mendeteksi kejadian *radial run-out* berkategori tinggi. Efek perbaikan pada komponen lot *Tread* dan *Bead* yang dihasilkan dari *decision tree* dapat menurunkan tingkat *defect radial run-out* ban sebesar 99,9%.

**Kata Kunci:** Decision tree; Analisa akar masalah; Radial run-out ban; Data mining

### ABSTRACT

*Problem solving in the multistage production process is a challenge for the industry. The use of modern techniques such as machine learning in solving quality problems continues to be developed. One of the machine learning is decision tree. The tire industry entered the era of industrial revolution 4.0 with the use of information technology. Utilizing data using machine learning in finding the root cause of the problem can support the tire industry in industrial competition. This study aims to explore the process data in the tire industry to solve one of the tire quality problems, namely radial run-out tires. The technique of finding the root of the problem in this research is done using Classification and Regression Tree (CART) technique. Input variables involve 60 factors in the production process. From the research, it was found that the factors that influence the radial run out value are the lot of the Tread, Bead and Sidewall components. The factors causing the high radial run-out of the tires are the variations in the lot of the tire components Tread and Bead. The decision tree model that was formed has a precision level of 74.7% in detecting high radial run-out events. The effects of improvement on the lot tread and bead components resulting from the decision tree can reduce the defect of radial run out rate by 99.9%.*

**Keywords:** Decision tree; Root cause analysis; Radial run-out Tire; Data mining

## 1. PENDAHULUAN

Pemecahan permasalahan industri manufaktur sangat beragam dari pemecahan masalah yang paling sederhana *plan-do-check-action* (PDCA) sampai yang lebih kompleks seperti *six sigma*. Seiring dengan berkembangnya teknologi informasi maka teknik pemecahan masalah terus berkembang dan dikombinasikan dengan teknik-teknik modern seperti *machine-learning*.

Pemanfaatan data lampau dilakukan untuk mendapatkan pola-pola atau informasi yang ada di dalam kumpulan data atau dikenal sebagai *data mining*.

Proses produksi yang panjang/ *multistage* sangat membutuhkan teknik pemecahan masalah yang cepat. Kesulitan dalam pemecahan masalah pada proses *multistage* adalah kompleksitas proses melibatkan banyak variabel sehingga proses pencarian akar masalah lebih sulit. Variabel kemungkinan penyebab permasalahan sangat banyak dan bisa jadi juga merupakan kombinasi dari beberapa proses yang saling berinteraksi. Tanpa ada dukungan teknologi informasi maka pencarian akar masalah memakan waktu lama. Semakin lama proses pemecahan masalah dilakukan maka kerugian waktu proses ataupun jumlah produk tidak standar semakin besar.

Upaya peneliti menjawab tantangan dalam pemecahan permasalahan proses produksi *multistage* banyak dilakukan. Analisa model *forward* yaitu model dikembangkan dengan menganalisa kondisi proses sebelum dan memprediksi hasil pada proses berikutnya (Wuest, Irgens, & Thoben, 2014), (P. Jiang, Jia, Wang, & Zheng, 2014). Analisa model *backward* yaitu pencarian penyebab yang terjadi pada proses sebelumnya dengan melihat kondisi hasil yang ada seperti (Arif, Suryana, & Hussin, 2013), (Kao, Hsieh, Chen, & Lee, 2017). Model *forward* lebih banyak digunakan sebagai sistem kontrol atau monitoring proses sedangkan pada model *backward* lebih ditujukan dalam pencarian akar masalah yang menyebabkan produk tidak sesuai standar.

Industri ban adalah salah satu contoh proses produksi yang bersifat *multistage*. Dari bahan baku sampai menjadi produk jadi melibatkan beberapa tahapan proses antara lain pembentukan komponen ban, proses perakitan, proses pemasakan dan proses pemeriksaan produk akhir (Darayi, Eskandari, & Geiger, 2013). Kualitas akhir dari produk ditentukan oleh kualitas material dan perlakuan dalam proses produksi. Analisa masalah terhadap produk akhir yang tidak masuk standar kualitas membutuhkan analisa yang rumit dikarenakan banyaknya variabel proses pada proses produksi yang panjang.

Pemanfaatan teknologi informasi seperti *barcode* ataupun *radio frequency identification* (Gao, Yang, & Ning, 2010) sangat membantu dalam melakukan kemampuan telusur produk dengan sangat cepat. Pemakaian teknologi mutakhir pada industri ban menjadi kebutuhan dalam menghadapi kompetisi industri yang tinggi dan menyongsong revolusi industri 4.0 (Biantoro, Trimarjoko, Purwanto, & Rimawan, 2019). Transaksi proses produksi dapat dilakukan secara elektronik dan tingkat automasi yang tinggi. Data proses produksi tersedia secara elektronik memudahkan proses telusur dan merupakan peluang untuk pemanfaatannya. Penelitian ini bertujuan untuk memanfaatkan data proses untuk meningkatkan kualitas produk menggunakan teknik data mining. *Decision tree* (DT) adalah salah satu teknik data mining untuk pencarian akar masalah membantu memperbaiki kualitas produk. Sebagaimana (Mueller, Greipel, Weber, & Schmitt, 2018) melakukan simulasi otomatisasi pencarian akar masalah menggunakan DT.


## 2. LITERATUR REVIEW

### *Radial Run-Out Ban*

Ban merupakan produk *composite* yang terdiri dari beberapa komponen. Ban berfungsi sebagai penahan beban dan pengarah kendaraan. Harapan pelanggan terhadap kualitas ban adalah aspek kekuatan dan aspek *fashion* (Hadi et al., 2017). Kualitas ban dapat memberikan pengaruh pada kenyamanan berkendara. Salah satu kriteria kualitas ban yang berpengaruh terhadap

kenyamanan adalah radial run-out ban(RRO) (Kenny, 1989). Mengingat pentingnya pengaruh RRO terhadap kenyamanan pengendara maka RRO menjadi obyek dalam penelitian ini.

RRO adalah ukuran kebulatan ban terhadap titik tengah perputaran ban. Ilustrasi RRO pada Gambar 1. Pengukuran RRO dalam satuan millimeter. Pengukuran RRO dilakukan secara otomatis pada mesin inspeksi pada proses final inspection atau tahap akhir produksi. Hasil pengukuran RRO tercatat bersama dengan *barcode identification* yang dapat ditelusur ke proses produksi.



Gambar 1. Radial Run Out tire

### Decision Tree

*Decision tree* (DT) merupakan salah satu teknik klasifikasi yang digunakan dalam sistem pendukung keputusan. Bagian dari model DT terdiri dari simpul/*node* dan cabang/*branch*. Setiap node menunjukkan *feature* penting dan setiap cabang menunjukkan keputusan (Chandrasekaran, Sonawane, Arulmozhi, & Sriramy, 2020). DT dilakukan dengan menggunakan teknik atau urutan process sebagai berikut:

- Deskripsi statistik untuk melihat distribusi data dan uji normalitas data. Pada analisis DT distribusi data normal menghasilkan DT yang lebih baik dibandingkan distribusi data tidak normal (Mueller et al., 2018).
- Konfirmasi faktor untuk menentukan faktor utama yang berkontribusi terhadap variabel output. Tahap ini dilakukan jika faktor input sangat kompleks untuk menghindari hasil DT yang rumit. Penelitian dengan melibatkan variabel input kurang dari 10 seperti (Mellisa, 2019), (Mueller et al., 2018) tidak melakukan pemilihan variabel, sedangkan penelitian dengan lebih dari 10 variabel input (Song & Lu, 2015) melakukan pemilihan variabel dominan. Penelitian dengan menggunakan pemilihan variabel dominan menunjukkan hasil akurasi dan presisi DT yang lebih baik (Arif et al., 2013) (Chokka & Rani, 2019).
- Melakukan analisa DT untuk mengetahui faktor yang berpengaruh. Langkah langkah dalam analisa DT model adalah pembuatan diagram DT meliputi pemisahan/*splitting* dan pemberhentian/*stopping criteria*. DT yang terbentuk belum tentu menghasilkan kombinasi reule set yang optimal. Proses pemangkasan/ *pruning* terhadap cabang-cabang DT dapat dilakukan untuk meningkatkan performance DT (Seema, Rathi, & Mamta, 2012).

Algoritma teknik DT beragam, pada umumnya digunakan adalah CART (*Classification and regression tree*), C4.5, CHAID (Chi-square Automatic Interaction Detection), QUEST (Quick

and Unbias, Efficient, Statistical Tree). Perbandingan pada masing masing metode terletak pada jenis data input dan variabel output serta pada proses pembentukan DT (Song & Lu, 2015). Penelitian ini bertujuan untuk menemukan akar masalah yang mempengaruhi tingginya nilai RRO. Teknik DT pada penelitian ini digunakan metoda CART dimana variabel input dan output berbentuk kategori.

Evaluasi performance DT dapat dilakukan dengan melihat ketepatan model memprediksi sample. Pada penelitian bersifat memprediksi ketepatan prediksi positif dan negative model maka indeks *accuracy* umum digunakan untuk menilai *performance* model. Sedangkan untuk kasus penelitian yang hanya berfokus pada kebenaran model dalam memprediksi *positive* saja maka digunakan ukuran *precision* dan *recall* (C. Jiang, Liu, Ding, Liang, & Duan, 2017).

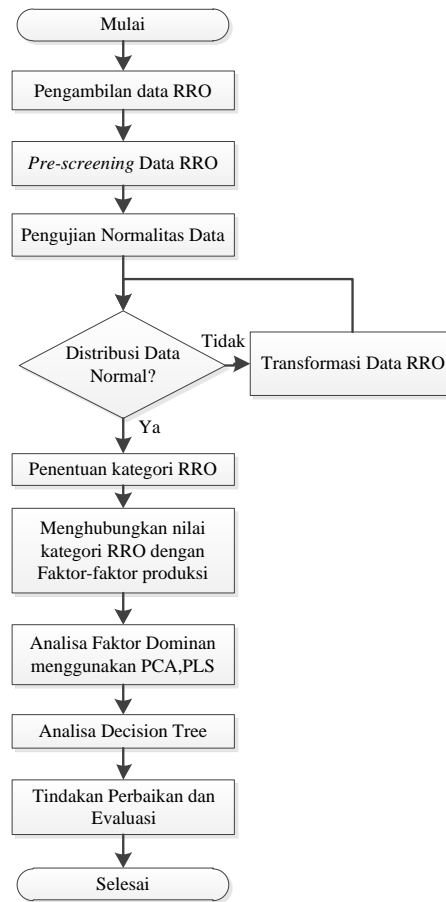
Akurasi model DT berdasarkan simulasi (Mueller et al., 2018) dalam menentukan akar masalah ditentukan oleh faktor-faktor berikut ini :

- Bentuk distribusi normal menghasilkan DT yang lebih baik dibandingkan dengan distribusi data uniform
- Jumlah perbandingan antara produk Not OK dalam data minimal 7%. DT tidak dapat mendeteksi akar masalah jika jumlah produk not OK kurang dari 7%.
- Jumlah sample lebih banyak dapat meningkatkan akurasi dari model DT
- Semakin banyak kategori pada variabel maka model DT performancenya semakin menurun. Kondisi optimum pada simulasi adalah 15 kategori dalam variabel.

### 3. METODE

Berdasarkan *literature review* dan sifat objek yang diteliti maka penelitian ini dilakukan melalui tahapan sebagaimana pada Gambar 2. Tahapan penelitian meliputi:

- Analisa deskriptif untuk sifat data RRO dengan melakukan uji normalitas data RRO dan melakukan transformasi data yang diperlukan. Diskretisasi nilai RRO menjadi dua kategori yaitu *high* dan *low* kategori.
- Menghubungkan nilai RRO terhadap faktor faktor produksi yang dilalui meliputi informasi operator, mesin, material dan waktu pembuatan.
- Pencarian variabel utama untuk menyeleksi variabel kandidat yang ada sehingga dapat meningkatkan akurasi dari DT melalui analisa *principal component analysis* (PCA) dan *partial least square* (PLS).
- Melakukan analisa DT dengan metoda *classification tree* dengan variabel dependen adalah RRO yang telah di kategorikan dan faktor produksi yang menjadi variabel dominan sebagai variabel Independen
- Evaluasi model DT yang ada dan menentukan faktor- faktor penyebab tingginya nilai RRO
- Perbaikan terhadap faktor penyebab yang ditemukan pada model DT dan mengevaluasi pengaruh perbaikan pada tingkat *defect* produk.

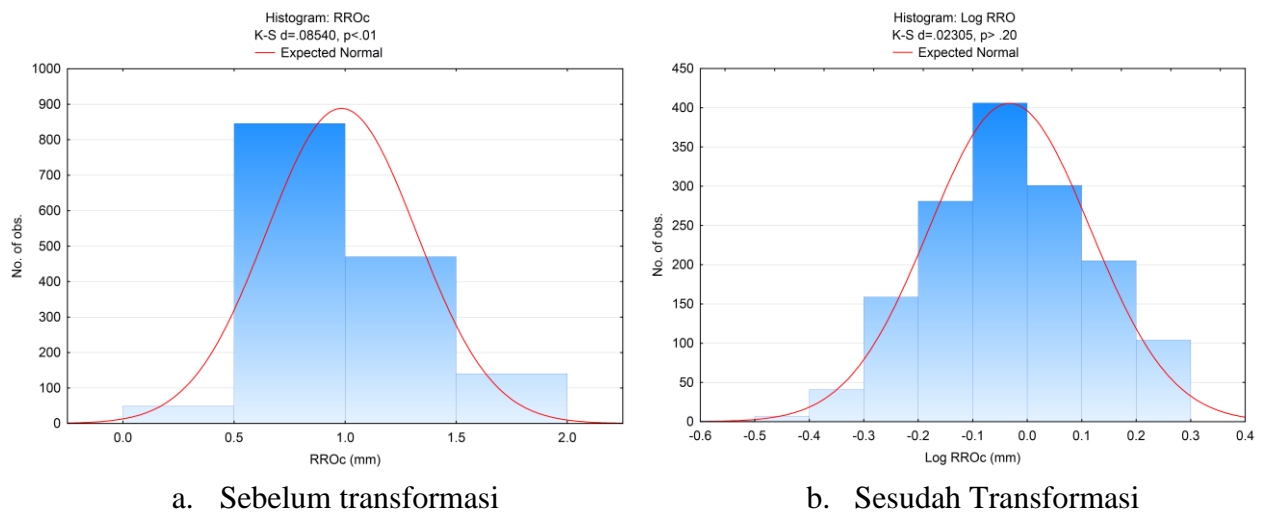


Gambar 2. *Flow chart* penelitian

#### 4. HASIL DAN PEMBAHASAN

Data penelitian yang digunakan adalah data RRO ban selama proses inspeksi satu bulan pada produk ban truk dan bis yang digunakan pada posisi *steer* atau pengemudi. Jumlah total data 1480 pcs data. Deskripsi dari data RRO, dapat dilihat pada Gambar 3. Pada Gambar 3a terlihat distribusi data RRO condong ke arah negative dan hasil uji normalitas berdasarkan Kolmogorof Smirnof (K-S d)  $p < 0.05$  menandakan bahwa data RRO tidak berdistribusi normal. Transformasi nilai data RRO dilakukan menggunakan persamaan 1 menjadi RROt. Gambar 3b menunjukkan histogram data RROt yang sudah ditransformasi. Nilai K-S d untuk p adalah 0.20 yang menunjukkan distribusi data sudah normal.


$$\text{RROt} = \text{Log} (\text{RRO}) \quad (1)$$



Gambar 3. Histogram data RRO

Pembagian variabel output menjadi kategori bergantung pada sifat produk. Penelitian (Mueller et al., 2018) dengan sifat produk pada nilai target tertentu membagi kelas menjadi dua dengan ketentuan nilai sesuai toleransi menjadi kelas *OK* dan nilai diluar toleransi menjadi *not-OK*. Variabel output penelitian ini bersifat nilai tagetnya adalah semimumum mungkin. Pembagian kelas RRO menjadi dua dengan ketentuan nilai RROt lebih besar atau sama dengan 0 dikategorikan sebagai *high* RRO dan RROt<0 dikategorikan sebagai *low* RRO. Dengan cara demikian maka jumlah *high* RRO dalam data adalah sebesar 41.3%. Jumlah *high* RRO ini memenuhi kriteria minimum untuk digunakan dalam analisa akar masalah dengan model DT.

Pada setiap data ban terdapat no unik atau *barcode identification* yang dapat digunakan sebagai *traceback* terhadap proses produksi sehingga didapatkan data faktor-faktor proses produksi. Data penelitian melibatkan data sejumlah 60 attribute. Sebanyak 4% data tidak lengkap dan di hilangkan pada proses selanjutnya. Penyederhanan variabel input dilakukan menggunakan *feature selection* pada software SAS yang berprinsip pada *principal component analysis* (PCA) dan *partial least square* (PLS). Gambar 4 menunjukkan 10 variabel input dominan yang mempengaruhi klasifikasi RROt.



Gambar 4. 10 Variabel Dominan terhadap RROt

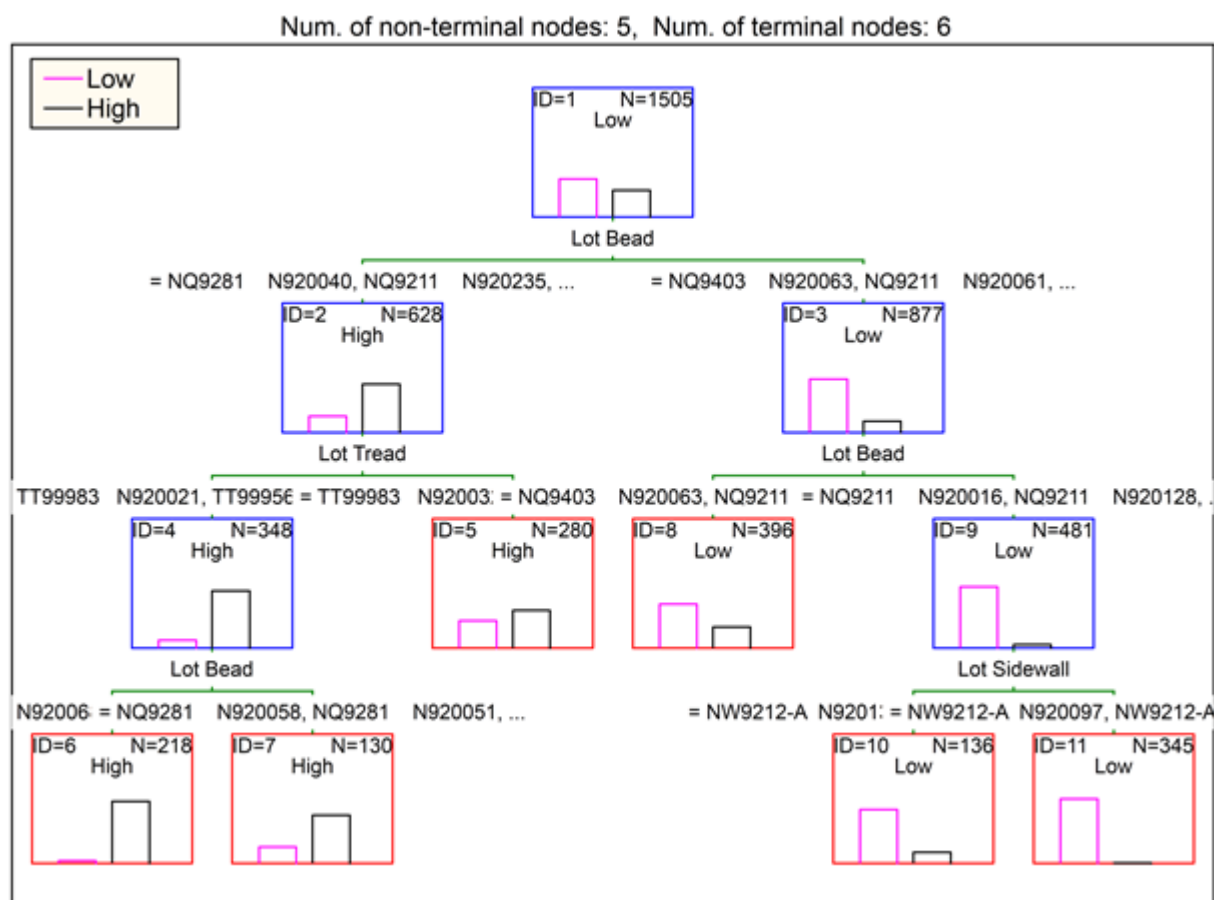
Tabel 1. Variabel untuk analisa DT

No	Attribut	Deskripsi	Jenis Variabel	Jenis data
1	RROt	Nilai Kualitas ban dalam satuan millimeter yang sudah ditransformasi	Dependent	kategori
2	Lot Bead	Lot material Bead	Independent	kategori
3	Lot Sidewall	Lot material Sidewall	Independent	kategori
4	Lot Tread	Lot material Tread	Independent	kategori
5	Lot Inner liner	Lot material Inner Liner	Independent	kategori
6	Lot BEC	Lot material Belt Edge Cushion	Independent	kategori
7	Lot Body Ply	Lot material Body Ply	Independent	kategori
8	Lot Steel Chafer	Lot material Steel Chafer	Independent	kategori
9	Curing_mcn	Nomer posisi mesin curing	Independent	kategori
10	Code	Jenis produk ban	Independent	kategori

DT analisis menggunakan software SAS dengan metoda *interactive decision tree CART*. DT dikembangkan berdasarkan kondisi pemisahan indek menggunakan gini indeks dan kriteria pemberhentian adalah jumlah node minimal 125 data. Penentuan kriteria perberhentian ini dilakukan dengan mempertimbangkan tingkat kompleksitas DT yang akan dihasilkan dan tujuan dari DT untuk mencari faktor dominan akar masalah *high RRO* (Song & Lu, 2015). Semakin tinggi tingkat kompleksitas akan semakin sulit dalam menentukan faktor dan semakin rumit dalam dilakukan perbaikan.

Gambar 4 menunjukkan bahwa DT yang terbentuk memiliki jumlah non terminal *node* sebanyak 5 dan terminal *node* sebanyak 6. Dari 10 variabel yang terlibat hanya 3 variabel yang muncul. Hal ini menandakan bahwa 3 variabel ini dominan mempengaruhi nilai RRO. Pada model DT terlihat bahwa RROt dengan kategori *high* pada ada *node* ID no 2,4,5,6 dan 7 dengan melibatkan komponen lot tread dan lot bead. DT dapat menunjukkan komponen dan lot secara spesifik.

Evaluasi model DT dapat dilakukan dengan melihat *confusion* matrik sebagaimana pada Tabel 2. Pada penelitian ini fokus utama adalah mencari akar masalah dari tingginya nilai RRO oleh karenanya *precision* dan *recall* menjadi tolok ukur dalam menilai *performance* model DT. Tabel 2 menunjukkan bahwa DT dapat memprediksi kejadian *high RRO* sebesar 74.7% dan kebenaran hasil prediksi model DT pada *high RRO* adalah 76.4%. Evaluasi ini berbeda dengan penelitian yang bertujuan untuk menggunakan DT sebagai prediksi pada semua kondisi atau secara total yang umumnya menggunakan tingkat akurasi model.



Gambar 5. Decision Tree analysis RROt

Tabel 2. *Confusion matrix*

		Prediksi RROt	
		Low	High
Actual RROt	Low	711	158
	High	144	467
Precision		74,7%	
Recall		76,4%	

Perbaikan pada proses dengan fokus pada hasil analisa DT yaitu perbaikan pada komponen *Tread* dan *Bead* khususnya pada lot dengan kategori *high* RRO. Item perbaikan yang dilakukan adalah mengurangi variasi panjang komponen tread dan bead serta metode penyambungan komponen tersebut. Evaluasi terhadap hasil perbaikan kedua komponen dilakukan dengan melihat tingkat defect RRO ban. Perbandingan defect RRO ban menunjukkan penurunan defect RRO dari 8.69% menjadi 0.19% atau berkurang sebesar 99.9%.

## 5. KESIMPULAN

Berdasarkan analisa DT maka dapat disimpulkan bahwa:

- Kategorisasi output menjadi OK- not OK atau bad-good tergantung pada sifat produk atau variabel yang dianalisa.



- Pada proses penentuan stopping kriteria harus diseimbangkan antara kompleksitas model DT dengan tujuan DT. Analisa DT yang bertujuan untuk pencarian faktor dominan masalah dapat menggunakan DT lebih sederhana.
- Tidak semua faktor dominan yang terlibat dalam DT akan muncul. Faktor akan muncul dalam DT ketika stoping *criteria* telah terpenuhi. Faktor dominan yang muncul dalam DT adalah lot komponen *Tread*, *Bead* dan *Sidewall*. Faktor penyebab permasalahan *high* RRO ban pada penelitian ini adalah lot komponen *Tread* dan *Bead*.
- Perbaikan terhadap akar masalah yang diidentifikasi melalui DT menghasilkan penurunan defect RRO secara signifikan.

Penelitian penggunaan DT dalam mencari akar masalah untuk permasalahan kualitas masih perlu dikembangkan. Penentuan *stopping criteria* optimal perlu di uji agar tingkat kompleksitas dan tingkat *precision* model berjalan seimbang.

### Ucapan Terima Kasih

Penelitian ini didukung oleh Kementerian Pendidikan / Kepala Badan Riset dan Inovasi Nasional Republik Indonesia melalui Program Magister Hibah Penelitian Tesis (PTM) Tahun 2020 dan Lembaga Penelitian dan Pengabdian kepada Masyarakat Universitas Mercubuana.

### REFERENSI

- Arif, F., Suryana, N., & Hussin, B. (2013). A data mining approach for developing quality prediction model in multi-stage manufacturing. *International Journal of Computer Applications*, 69(22), 35–40.
- Biantoro, B., Trimarjoko, A., Purwanto, C., & Rimawan, E. (2019). Case Study : Acceptance Analysis for New Tire Building Machine Technology using Overall Equipment Effectiveness Methodology. *International Journal of Innovative Science and Research Technology*, 4(1).
- Chandrasekaran, M., Sonawane, P. R., Arulmozhi, P., & Sriramy, P. (2020). Prediction of Gear Pitting Defect by Using Decision Tree Classifier Machine Learning Algorithm. *Journal of Critical Reviews*, 7(9), 159–162.
- Chokka, A., & Rani, K. S. (2019). PCA based regression decision tree classification for somatic mutations. *International Journal of Engineering and Advanced Technology*, 8(6 Special Issue 3), 1095–1102. <https://doi.org/10.35940/ijeat.F1181.0986S319>
- Darayi, M., Eskandari, H., & Geiger, C. D. (2013). Using Simulation-Based Optimization to Improve Performance At a Tire Manufacturing Company. *QScience Connect*, 13.
- Gao, Y., Yang, D., & Ning, W. (2010). Research on Manufacturing Process Traceability in Tire Enterprise. *Applied Mechanic and Material*, 47(December), 485–488. <https://doi.org/10.4028/www.scientific.net/AMM.44-47.485>
- Hadi, H. A., Purba, H. H., Indarto, K. S., Gomgom, R., Simarmata, P., & Putra, G. P. (2017). The implementation of quality function deployment (QFD) in tire industry. *ComTech*, 8(4), 223–228.
- Jiang, C., Liu, Y., Ding, Y., Liang, K., & Duan, R. (2017). Capturing helpful reviews from social media for product quality improvement: a multi-class classification approach. *International Journal of Production Research*, 7543(March), 0. <https://doi.org/10.1080/00207543.2017.1304664>
- Jiang, P., Jia, F., Wang, Y., & Zheng, M. (2014). Real-time quality monitoring and predicting model based on error propagation networks for multistage machining processes. *Journal of Intelligent Manufacturing*, 25(3), 521–538. <https://doi.org/10.1007/s10845-012-0703-0>

- Kenny, T. M. (1989). Quantifying Tire, Rim and Vehicle Effect on Ride Quality. In *International Congress and Exposition* (pp. 1–9). Detroit, Michigan, USA: SAE.
- Mellisa, I. (2019). Building Data Mining Decision Tree Model for Predicting Employee Performance. *Journal of Applied Information Communication and Technology*, 6(2), 75–86. <https://doi.org/10.33555/ejaict.v6i2.79>
- Mueller, T., Greipel, J., Weber, T., & Schmitt, R. H. (2018). Automated Root Cause Analysis of Non-conformities with Machine Learning Algorithms. *Journal of Machine Engineering*, 18(4), 60–72.
- Seema, Rathi, M., & Mamta. (2012). Decision Tree: Data Mining Techniques. *International Journal of Latest Trends in Engineering and Technology (IJLTET)*, 1(3), 150–155.
- Song, Y., & Lu, Y. (2015). Decision tree methods : applications for classification and prediction. *Shanghai Arch Psychiatry*, 27(2), 130–135.
- Wuest, T., Irgens, C., & Thoben, K. D. (2014). An approach to monitoring quality in manufacturing using supervised machine learning on product state data. *Journal of Intelligent Manufacturing*, 25(5), 1167–1180.